

(19) Japanese Patent Office (JP)

(12) Patent Publication (B2)

(11) Publication after Examination No. JP 8-12684 B2

(24) (44) Date of Publication after Examination: February 7, 1996

(51) Int.Cl. ⁶	ID code	In-office No.	FI
G06K 9/68	A	9061-5H	
G06T 7/00		9061-5H	G06F 15/70 450
			Number of Claims: 1

(21) Patent Application No. : 3-195468

(22) Date of Application : August 5, 1991

(65) Publication before Examination No. : 5-40852 A

(43) Date of Publication before Examination: February 19, 1993

(71) Applicant : SCIENCE & TECH AGENCY
2-1, Kasumigaseki 2-chome, Chiyoda-ku, Tokyo

(72) Inventor : KURUMI, Masatoshi
c/o OMRON Corp.
10, Hanazono-tsuchido-cho, Ukyo-ku, Kyoto

(74) Agent : Shigenori Wada, Patent Attorney

Examiner : Makoto Hirai

(56) References Cited: JP 3-3089 A
JP 1-321591 A
JP 56-105586 A
JP 62-114082 A

(19) 日本国特許庁 (J P)

(12) 特 許 公 報 (B 2)

(11) 特許出願公告番号

特公平8-12684

(24) (44) 公告日 平成 8 年 (1996) 2 月 7 日

(51) Int.Cl. ⁶	識別記号	庁内整理番号	F I	技術表示箇所
G 0 6 K 9/68		A 9061-5H		
G 0 6 T 7/00				
		9061-5H	G 0 6 F 15/ 70	4 5 0

請求項の数 1 (全 12 頁)

(21) 出願番号	特願平3-195468	(71) 出願人	592146265 科学技術庁長官官房会計課長 東京都千代田区霞ヶ関二丁目2番1号
(22) 出願日	平成3年(1991)8月5日	(72) 発明者	来海 雅俊 京都府京都市右京区花園土堂町10番地 オ ムロン株式会社内
(65) 公開番号	特開平5-40852	(74) 代理人	弁理士 和田 成則
(43) 公開日	平成5年(1993)2月19日		
		審査官	平井 誠
		(56) 参考文献	特開 平3-3089 (J P, A) 特開 平1-321591 (J P, A) 特開 昭56-105586 (J P, A) 特開 昭62-114082 (J P, A)

(54) 【発明の名称】 パターン認識装置

1

【特許請求の範囲】

【請求項1】 多次元データ解析による複数の主成分軸上での類似度によってパターンを認識するパターン認識装置において、
上記主成分軸の長さが所定値以上の主成分軸上での類似度は予め設定された類似度に関するメンバーシップ関数を適用して算出し、上記主成分軸の長さが所定値以下の主成分軸上での類似度は主成分軸上の分散の近似値を算出してパターン認識することを特徴とするパターン認識装置。

【発明の詳細な説明】

【0001】

【産業上の利用分野】 この発明は、文字パターン等の認識装置に関し、特に多次元データ解析における特徴量空間を利用してパターンを認識するパターン認識装置に関

2

する。

【0002】

【従来の技術】 従来より、文字パターン等の認識アルゴリズムの中で、特徴抽出と並んで重要なのが識別関数である。

【0003】 そして、識別関数の中で、最もベーシックなものはユークリッド距離であり、次式で表される。

【0004】

【数1】

10

$$E D (x) = \sum_i^n (x_i - m_i)^2$$

【0005】 ここで、x は入力パターンベクトルであり、 x_i はその各成分、 m_i は認識しようとするカテゴリの標準パターンベクトルの各成分である。また、特徴

量の次元数は n である。

【0006】この識別関数は簡単であり、処理速度も速いので、パターン認識の世界ではよく使われている。しかし、識別しようとするカテゴリを標準パターンベクトル（普通は平均ベクトルが使われる）ひとつで表現しようとするところに無理があり、データ分布が複雑になってきたり、文字認識のような多カテゴリの場合には性能上、問題があった。

【0007】そこで、データの分布を考慮したものとして、マハラノビス距離が使われている。

【0008】いま、これを例えば図7に示した文字パターン20を認識する場合を例にとって説明すると、学習用文字パターン20を、同図に示す如く、例えば、 $D_1, D_2, D_3, \dots, D_{64}$ の64画素に分割して、図8に示す如く64次元の特徴量空間30でベクトル表現として得る。

【0009】そして、各文字パターン毎に多数のサンプ*

$$MD(x) = \sum_{i=1}^n \frac{1}{\lambda_i} ((x-m) \cdot \phi_i)^2$$

【0015】ここで ϕ_i と λ_i は、識別カテゴリの学習データの共分散行列から得られる固有ベクトルと固有値であり、それぞれ、データ分布の主成分ベクトルと、主成分軸上の分散の値に一致する。

【0016】一方、学習データの分布から確立密度関数を近似して、それをもとにベイズ決定機構を用いて識別※

$$P_i(x) = (2\pi)^{-\frac{1}{2}} \cdot \lambda_i^{-\frac{1}{2}} \cdot \exp\left(-\frac{1}{2\lambda_i} ((x-m) \cdot \phi_i)^2\right)$$

【0018】で表され、また、各主成分軸が統計的に独立だとすると、パターン空間全体における x の確立密度関数は

$$P(x) = \prod_{i=1}^n P_i(x)$$

$$= (2\pi)^{-\frac{n}{2}} \cdot \prod_{i=1}^n \lambda_i^{-\frac{n}{2}}$$

$$\times \prod_{i=1}^n \exp\left(-\frac{1}{2\lambda_i} ((x-m) \cdot \phi_i)^2\right)$$

【0020】となり、両辺の対数をとると

【0021】

*ルデータを得る。図9は、図8に示した文字パターン20のサンプルデータの分布の例である。

【0010】そして、この学習サンプルについて主成分分析を行い、各主成分軸上のサンプルの出現確立を図12(a)に示す如き正規分布25で仮定する。

【0011】ここで、未知のパターンが入力されると、例えば64次元での多次元データ回析の場合、64の各軸上で出現確立を求め、その確立が最も高くなるような文字パターンに未知パターンを識別する。

10 【0012】すなわち、図10は64次元の特徴量空間での主成分展開を示し、 ϕ_1 は第1主成分の固有ベクトル、 ϕ_2 は第2主成分の固有ベクトルを示しているが、この場合は図11に示す如く座標交換する。

【0013】そして、この場合は次式が演算されることになる。

【0014】

【数2】

※する方法もある。例えば、データ分布を主成分展開した後、各主成分軸上でデータが正規分布していると仮定すると、ある主成分軸 i での確立密度関数は

【0017】

【数3】

★【0019】

【数4】

【数5】

$$\ln P(x) = -\frac{1}{2} \left\{ n \cdot \ln(2\pi) + \ln \prod_{i=1}^n \lambda_i \right. \\ \left. + \sum_{i=1}^n \frac{1}{\lambda_i} ((x-m) \cdot \phi_i)^2 \right\}$$

【0022】となる。ここで、次のような識別関数を考
えたと、確立密度関数に対して単調減少となり、この値
が小さいほど確立密度の値が大きくなる。 *【0023】
【数6】

$$BD(x) = \sum_{i=1}^n \frac{1}{\lambda_i} ((x-m) \cdot \phi_i)^2 + \ln \prod_{i=1}^n \lambda_i$$

【0024】この式はベイズ識別関数と呼ばれており、
データの確立密度関数を反映した式になっているので、
いい標本サンプルを集めることができれば、理論的には
最適な識別関数となる。

【0025】

【発明が解決しようとする課題】しかしながら、上記の
如き従来方式にあっては、各主成分軸上でのサンプル出
現確率を平均値を中心とする正規分布で仮定している
が、実際には、図12(b)に示す関数26の如く正規
分布をなさない場合も多く、この場合は、仮定した確率
密度関数と現実のサンプルの出現確率が異なって、パ
ターン認識の精度が低下するという不具合があった。

【0026】また、文字などの認識においては、学習サ
ンプルの分布による出現確率と人間の感じる類似度の分※

※布が異なり、同じく、一律に正規分布で仮定する上記の
如き手法ではパターン認識の精度が低下するという不具
合があった。

【0027】そこで、近年、類似度の分布関数を図12
(C)に示す如く、メンバーシップ関数27の形で表すフ
ァジィパターン認識方式が提案されている。

【0028】これは、学習用サンプルデータが得られる
と、このサンプルデータに基いて各画素毎にメンバーシ
ップ関数を作成し、未知パターンが入力されるとこのメ
ンバーシップ関数を適用してパターンの識別を行うもの
である。

【0029】すなわち、

【0030】

【数7】

x を未知パターンベクトル、

ℓ x をカテゴリ ℓ の平均パターン、

ℓ ϕ_i をカテゴリ ℓ の第 i 主成分ベクトル(単位ベクトル)、

ℓ $M_i(\quad)$ をカテゴリ ℓ の第 i 主成分のメンバーシップ関数、

\cdot をベクトルの内積、

$F_\ell(x)$ をカテゴリ ℓ と入力ベクトル x との距離

【0031】として、次式数8よりパターン認識するも ★【0032】
ので、数8の値が最大のカテゴリにパターン認識するも 40 【数8】
のである。 ★

$$F_\ell(x) = \sum_{i=1}^n \frac{1}{\pi} \ell M_i((x - \ell x) \cdot \ell \phi_i)$$

【0033】しかしながら、このようなファジィパター
ン認識方法を利用してパターン認識する手法では、上記
の不具合は回避できるが、特徴量の次元数が上記の如
く、例えば64と大きくなったとき、識別データ(以
下、辞書という)に全てのカテゴリについての全ての主
成分軸についてメンバーシップ関数を作成する必要がある 50

るので、辞書容量が大きくなるとともに、パターン認識
時に全ての軸について主成分展開しなければならないの
で、処理時間に多大の時間を要するという不具合があっ
た。

【0034】この発明は、上記の如き従来の課題に鑑み
てなされたもので、その目的とするところは、辞書容量

を小さくでき、かつ識別時間を大幅に低減することのできるパターン認識装置を提供することにある。

【0035】

【課題を解決するための手段】この発明は、上記目的を達成するために、多次元データ解析による複数の主成分軸上での類似度によってパターンを認識するパターン認識装置において、上記主成分軸の長さが所定値以上の主成分軸上での類似度は予め設定された類似度に関するメンバーシップ関数を適用して算出し、上記主成分軸の長さが所定値以下の主成分軸上での類似度は主成分軸上の分散の近似値を算出してパターン認識することを特徴とする。

【0036】

【作用】この発明では、主要な主成分軸上での類似度のみにメンバーシップ関数を作成してパターンの識別を行うので、メンバーシップ関数作成のための手間が軽減され、また、パターン認識のための処理時間も低減される。

【0037】

【実施例】以下、本発明を図面に基いて説明する。

【0038】図1は本発明が適用された実施例の電気的な構成を示すブロック図である。

【0039】まず構成を説明すると、1はCPU等よりなる中央制御部で、この中央制御部1にはバスライン2を介して入力部3、前処理部4、特徴抽出部5、主成分展開部6、メンバーシップ値算出部7、類似度算出部8、判定部9、出力部10が接続され、さらにバスライン2にはRAMよりなる作業領域11、RAMやROMよりなる主成分辞書12、メンバーシップ関数辞書13が接続されている。なお、入力部3はイメージセンサ等より構成され、出力部10は表示器等で構成される。また、前処理部4、特徴抽出部5、主成分展開部6、メンバーシップ値算出部7、類似度算出部8および判定部9はCPU等より構成される。

【0040】以上が本実施例の構成であり、以下その作用を説明する。

【0041】なお、以下の説明でも文字パターンを認識する場合について説明する。

【0042】まず、本実施例においても図2に示す如く辞書作成処理を行う。

【0043】いまこれを図4～図6を参照しながら説明すると、まず辞書登録しようとする文字パターン20を、図4(a)に示す如くスキャナ等の入力部3より読み取って入力する(ステップ210)。

【0044】こうして文字パターン20が入力されると、ステップ220の前処理を行い、ノイズ成分を除去するとともに、図4(b)に示す如く、規格化された一定の大きさに拡大または縮小処理を行った文字パターン21を得る。

【0045】つぎに、ステップ230の特徴量抽出処理

を行うが、これには図4(c)に示す如く、図4(b)の文字パターン21にガウスフィルタをかけた文字パターン22を使用する。

【0046】すなわち、本実施例においても図7に示す如く、文字パターン20を例えば64画素に分割して、多次元データ解析における特徴量空間において各画素毎の主成分軸上の特徴量を抽出するが、このような特徴量抽出処理は、もとの文字パターン20に図5に示す如きガウスフィルタ40をかけたものを使用する。

【0047】ガウスフィルタ40は、図7に示した D_1 、 D_2 、 D_3 等の各画素と同一大の大きさを有する複数の正方形のフィルタ領域より構成され、中央部分に中心フィルタ41を有し、周囲にも中心フィルタ41を中心にして放射状に伸びた複数のフィルタ領域を有している。ところで、この場合、中心フィルタ41が重ね合わされる画素部分には例えば100の重みで、そして周辺の画素部分には図5に示したそれぞれの重み付けで図4(b)に示した文字パターン21を加工する。

【0048】これによって、図4(c)に示す如く、もとの文字パターン21より太字で、しかも文字輪郭の周囲には小さな重み付け値を有するフィルタ領域42、42、42、42に起因する薄い文字パターンを有する文字パターン22が得られることになる。

【0049】従って、ステップ230の処理では、まず図4(a)の形で入力された学習用文字パターン20が図4(c)に示す如き文字パターン22に交換され、サンプルデータとされることになる。

【0050】そして、つづくステップ240の処理では、サンプルデータに基いて主成分分析し、平均ベクトル(中心値)、ある値 k 軸までの主成分ベクトル、($k+1$)軸以降で64軸までの主成分軸上の分散の近似値 σ を求める。なお、この場合、主成分ベクトルが求められる画素の選択は、主成分軸の長さの長い軸から順番に選択される。これは、主成分軸が長いということはそれだけデータの分散度が大きいということであり、文字パターンの特徴的部分の画素である可能性が高いからである。また、($k+1$)軸以降について主成分ベクトルを求めないのは、後に詳述する如く、文字パターンの場合、例えば図7に示す如く、64の画素のうち、大部分の画素は文字パターン20を含まない空白部分で、何ら特徴量を含まない部分だからである。

【0051】つぎに、ステップ250では、 k 軸までの主成分について、主成分軸上の文字変形に対応するようなメンバーシップ関数を作成する。図6は、この場合のメンバーシップ関数の作成方法を示す説明図である。

【0052】同図には、メンバーシップ関数を求めようとする主成分ベクトルの中心ベクトル位置0を、プラス方向およびマイナス方向に単位距離毎にズラした場合の学習データが示されている。同図に示す如く、主要な成分については1単位距離だけ中心ベクトル位置がズレる

だけでも大きく異なって見える。従って、このデータに基づいてメンバシップ関数を作成する。そして、ステップ260では、ステップ240で得たデータを主成分辞書12に、またステップ250で得たデータをメンバシップ関数辞書13に登録する。以上の処理が各カテゴリ（文字）について行なわれ、登録されることになる。

【0053】以上が辞書作成処理の詳細である。

【0054】つぎに、このように辞書が作成されると、この作成辞書に基いて図3に示す如きパターン認識処理が行なわれる。

【0055】すなわち、まず、イメージセンサ等の入力*

x を未知パターンベクトル、

ℓ x をカテゴリ ℓ の平均パターン、

ℓ ϕ_i をカテゴリ ℓ の第 i 主成分ベクトル（単位ベクトル）、

ℓ M_i （ ）をカテゴリ ℓ の第 i 主成分のメンバシップ関数、

・をベクトルの内積、

$F_\ell(x)$ をカテゴリ ℓ と入力ベクトル x との距離

【0060】として数10を算出する。

※【数10】

【0061】

※

$$MF_\ell(x) = \frac{1}{\pi} \sum_{i=1}^{\ell} M_i((x - \ell x) \cdot \ell \phi_i)$$

$$\times \sum_{i=k+1}^{\infty} \frac{\pi}{\ell} \times P\left(-\frac{1}{2\sigma^2} ((x - \ell x) \cdot \ell \phi_i)^2\right)$$

【0062】ところで、

【0063】

【数11】

$$\exp(-MFD_\ell(x))$$

*部3によって未知パターンが入力されると（ステップ310）、辞書作成処理の場合と同様にして前処理を行い（ステップ320）、入力データの特徴量抽出処理を行う（ステップ330）。

【0056】つぎに、抽出された特徴量を主成分展開し（ステップ340）、 k 軸までは各主成分軸のメンバシップ関数、また $(k+1)$ 軸以降は分散 σ の正規分布関数に基いてメンバシップ値を求める。

【0057】そして、その全体の積を類似度とする。

【0058】すなわち、

【0059】

【数9】

【0064】は

【0065】

【数12】

$$\begin{aligned}
& \exp(-MFD_{\ell}(x)) \\
&= \exp \left\{ -\frac{1}{2\sigma} \|x - \ell x\|^2 + \sum_{i=1}^k \frac{((x - \ell x) \cdot \ell \phi i)^2}{2\sigma} \right. \\
&\quad \left. + \sum_{i=1}^k \log_{\ell} Mi((x - \ell x) \cdot \ell \phi i) \right\} \\
&= \exp \left\{ -\frac{1}{2\sigma} \sum_{i=k+1}^{\infty} ((x - \ell x) \cdot \ell \phi i)^2 \right\} \\
&\quad \times \exp \left\{ \log_{\ell} \prod_{i=1}^k Mi((x - \ell x) \cdot \ell \phi i) \right\} \\
&= \prod_{i=1}^k Mi((x - \ell x) \cdot \ell \phi i) \\
&\quad \times \sum_{i=k+1}^{\infty} \exp \left\{ -\frac{1}{2\sigma} ((x - \ell x) \cdot \ell \phi i)^2 \right\} \\
&= MF_{\ell}(x)
\end{aligned}$$

【0066】と展開できるので、数10は数13で示せる。
 * 【0067】
 * 【数13】

$$MFD_{\ell}(x)$$

$$\begin{aligned}
&= \frac{1}{2\sigma} \left[\|x - \ell x\|^2 - \sum_{i=1}^k \left\{ ((x - \ell x) \cdot \ell \phi i)^2 \right. \right. \\
&\quad \left. \left. + 2 \log_{\ell} Mi((x - \ell x) \cdot \ell \phi i) \right\} \right]
\end{aligned}$$

【0068】こうして、1番高い類似度をもつカテゴリに未知パターンを識別する。

【0069】以上説明したように、本実施例では、64次元の未知パターンを次のように識別する。

【0070】(1) 辞書作成時は、学習サンプルを主成分分析し、第k軸までは主成分ベクトルとその軸上のメ

ンバシッ関数、及び平均ベクトルを辞書として登録する。そして、第(k+1)軸以降は主成分軸上のメンバシッ関数を分散σの正規分布と仮定し、σのみを登録しておく。

【0071】(2) ここで未知パターンが入力されると、特徴量を抽出した後、それぞれのカテゴリに対して

主成分展開し、各主成分軸上でメンバーシップ値を求め、それらの積からカテゴリに対する類似度を求める。このとき、本実施例では第 $(k+1)$ 軸以降のメンバーシップ関数はすべて分散 σ の正規分布で表されているため、類似度を求める式は数10のようになる。また、数10は数13のように変形できるので、実際には数13を計算すればそのカテゴリに対する類似度が求まる。そして、求めた類似度の中で最も高い類似度をもつカテゴリに、未知パターンを識別する。

【0072】ところで、この場合、図7に示す如く、64の画素のほとんどは文字パターン20を含まず、一般には高次の主成分は分散がほとんど0に近く意味を持たないことが多い。従って、本実施例の如く一定値の分散の正規分布で表しても認識性能はほとんど変わらない。

【0073】したがって、本実施例による手法は従来のファジパターン認識手法に比べて、認識性能がほとんど変わらないまま、辞書容量が約 $k/64$ になり、かつ処理時間も約 $k/64$ になるという効果が得られる。

【0074】なお、本実施例では文字パターンを64画素で表現した場合について説明したが、画素の数の制限がないことは勿論である。

【0075】

【発明の効果】以上説明したように、この発明では、主要な主成分軸上での類似度のみ予め設定された類似度に関するメンバーシップ関数を適用して算出するようにしたので、辞書容量を小さくでき、かつ識別時間を大幅に低減することができるという効果を有する。

【図面の簡単な説明】

【図1】本発明が適用された実施例の電気的な構成を示すブロック図。

【図2】辞書作成の処理手順を示すフローチャート。

【図3】パターン認識処理の処理手順を示すフローチャート。

ート。

【図4】入力された学習用文字パターンをノイズ処理等をしてガウスフィルタをかける場合の説明図。

【図5】ガウスフィルタの説明図。

【図6】メンバーシップ関数の作成方法を示す説明図。

【図7】64画素で、学習用文字パターンの特徴量が抽出される場合の説明図。

【図8】特徴量空間における文字パターンの説明図。

【図9】特徴量空間における標本分布の説明図。

【図10】各固有ベクトルに基づき主成分展開する場合の説明図。


【図11】2つの固有ベクトルに基づき座標変換する場合の説明図。

【図12】類似度の分布を正規分布、非正規分布、メンバーシップ関数で表わした場合の説明図。


【符号の説明】

- 1 中央制御部
- 2 バスライン
- 3 入力部
- 4 前処理部
- 5 特徴抽出部
- 6 主成分展開部
- 7 メンバーシップ値算出部
- 8 類似度算出部
- 9 判定部
- 10 出力部
- 11 作業領域
- 12 主成分辞書
- 13 メンバーシップ関数辞書
- 20, 21, 22 学習用文字パターン
- 40 ガウスフィルタ

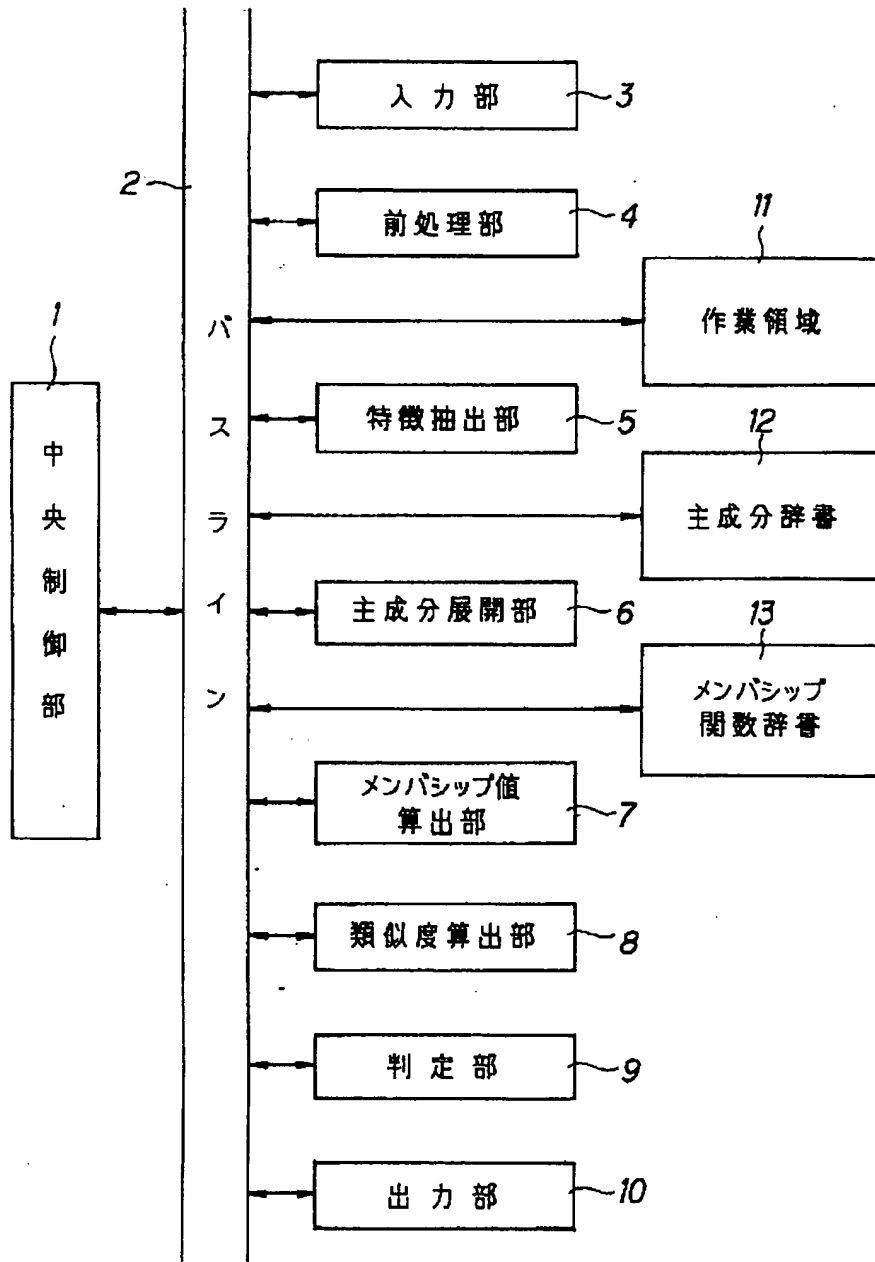
【図4】




【図5】




【図1】




【図2】




【図3】




【図7】




【図12】




【図 8】




【図 9】




【図6】



【図10】



【図11】



(19)



JAPANESE PATENT OFFICE

PATENT ABSTRACTS OF JAPAN

(11) Publication number: **05040852 A**

(43) Date of publication of application: 19 . 02 . 93

(51) Int. Cl.

G06K 9/68
G06F 15/70
(21) Application number: **03195468**(71) Applicant: **SCIENCE & TECH AGENCY**(22) Date of filing: **05 . 08 . 91**(72) Inventor: **KURUMI MASATOSHI**(54) **PATTERN RECOGNIZING DEVICE**

(57) Abstract:

PURPOSE: To improve the production efficiency of a pattern recognizing dictionary and also to shorten the pattern recognizing time.

CONSTITUTION: In a dictionary production state, the essential components of a 64-dimensional learning sample inputted through an input part 3 are analyzed. Then the essential component vectors covering up to the k-th ($k < 64$) axis and an average vector are registered in an essential component dictionary 12. At the same time, the membership functions of each axis are registered into a membership function dictionary 13. Meanwhile the membership functions of the essential component axes following the (k+1)-th one are supported as a normal distribution of dispersion σ , and only this σ is registered into the dictionary 12. If an unknown pattern is inputted, a feature extracting part 5 extracts the features of the pattern and an essential component evolving part 6 evolves the essential components in each category. A membership value calculation part 7 calculates the membership value and then calculates the resemblance of the categories from the product of the membership value. Under such conditions, the membership functions of the (k+1)-th and its subsequent

ones are shown in the normal distribution of the dispersion σ . Therefore the resemblance can be easily known among categories.

COPYRIGHT: (C)1993,JPO&Japio

